

İHA İLE MULTİSPEKTRAL KAMERALARDAN SAĞLANAN GÖRÜNTÜLER YARDIMIYLA BİTKİ TÜRLERİNİN SINIFLANDIRILMASI

F. Yıldız^{a,*}, Y. Doğan^a

^a Konya Teknik Üniversitesi, Harita Mühendisliği, Selçuklu Konya, Türkiye - fyildiz@ktun.edu.tr

ANAHTAR KELİMELER: İHA, Sınıflandırma, Bitki Türü, Multispektral, Uzaktan algılama, Yonca, Soya

ÖZET:

Yeryüzündeki bitki örtüsü türlerinin ayırt edilmesi uzaktan algılama çalışmalarında yoğun olarak kullanılmaktadır. Uydu görüntüleri kullanılarak yapılan bu uzaktan algılama çalışmaları, uyduların gerek her zaman aynı yerden görüntü elde edememesi gerekse yer örnekleme aralıklarından kaynaklanan sebeplerle zamansal ve mekânsal çözünürlükleri yüksek hassasiyet ve doğruluk istenen çalışmalarda yetersiz kalmaktadır. Bu çalışmada, son zamanlarda hızla artan ve yaygınlaşan İnsansız Hava Aracı (İHA) teknolojisinin esnek hareket kabiliyetine sahip olması nedeniyle sunmuş olduğu olanaklar üzerinde bir uygulama gerçekleştirilmiştir. İHA'ların istenilen zaman ve yer örnekleme aralığına uygun yükseklikte uçurulabilmesi esnek hareket kabiliyetine sahip olmasını sağlamaktadır. İHA üzerine yerleştirilen multispektral kameradan elde edilen görüntüler ile yeryüzündeki bitki örtüsü türlerinin tespiti yapıp sınıflandırılarak arazi kullanımlarının belirlenmesi ve ürün verimliliğinin araştırılması gibi konular uzaktan algılama çalışmalarına yeni bir bakış açısı kazandırabilir. İHA üzerine monte edilen kameranın elde ettiği yeşil, kırmızı, kırmızı-kenar ve yakın kızıl ötesi görüntüler kullanılarak yonca ve soya bitkilerinin tespit edilebilirliği incelenmiştir. Multispektral görüntülerden oluşturulan kompozit görüntüler yardımıyla tür sınıflandırması yapılmıştır.

KEY WORDS: UAV, Classification, Vegetation, Multispectral, Remote sensing, Clover, Soybean

ABSTRACT:

The distinction between the types of vegetation on earth is used extensively in remote sensing studies. Remote sensing studies using satellite imagery are inadequate in the studies requiring high accuracy and precise in temporal and spatial resolutions caused by frequency of revisit time and ground sample distance. In this study, an application was performed with the opportunities offering flexible mobility of unmanned aerial vehicle (UAV) technology which is rapidly increasing and widening recently. UAVs have flexible mobility thanks to the ability to fly at an altitude proper for the desired time and ground sampling distance. The multispectral imagery acquired from a camera mounted on a UAV. Determining the land uses and researching the product efficiency by classifying the species of vegetation on earth can give a new perspective to the remote sensing studies by using the images obtained from the multispectral camera mounted on the UAV. Detectability of clover and soybean was investigated using green, red, red-edge and near-infrared imagery obtained from multispectral camera. Vegetation classification was carried out by composite imagery created from multispectral imagery.

1. GİRİŞ

İHA'lar genellikle küçük alanlarda hızlı veri toplama, yüksek doğruluklu düşük maliyetli haritalama için uygun olduğundan çeşitli uygulamalar için kullanılabilir (Ahmad ve ark., 2013). İHA tabanlı spektral görüntüleme kullanımı, yüksek çözünürlüklü uzaktan algılama uygulamalarında önemli avantajlar sunmaktadır. Bununla birlikte, bir İHA üzerine monte edilebilen sensörlerin sayısı sınırlıdır ve spektral bantların optimal kombinasyonunun seçilmesi karmaşıktır ancak geleneksel İHA-tabanlı çoklu-görüşlü görüntüleme sistemleri için çok önemlidir (Ishida ve ark., 2018). Bitki örtüsünü ayırt etme yeteneği, İHA'ların görüntü spektrumu (kamera tipi), mekânsal (uçuş yüksekliği) ve zamansal (çalışma tarihi) çözünürlüklerinden önemli ölçüde etkilenmiştir. (Peña ve ark., 2015). Küçük termal, lazer veya spektral sensörler ile

donatılmış insansız hava araçlarının kullanımı, meralar, ormanlar ve tarımsal ortamlardaki uygulamaların modellenmesi, haritalanması ve izlenmesi için umut verici bir alternatif olarak ortaya çıkmıştır (Salami ve ark., 2014). Bitki örtüsü tespiti için İHA'lara monte edilen sensör sistemleri genellikle pasif sistemler olup güneşten yansıyan ışınları kullanırlar. Pasif optik sistemler ve özellikle hiperspektral sistemler genel olarak aktif SAR veya LiDAR sensör sistemlerine göre ağaç türlerinin sınıflandırılması için daha yüksek potansiyel göstermiştir (Fassnacht ve ark., 2016).

Somers ve Asner (2014) çalışmalarında spektral ve zamansal verileri kullanarak irdedikleri yaklaşımları sonucunda her pikselde mevcut olan ağaç türleri arasındaki spektral ayrımı optimize edebildiklerini belirtmektedir. Bitki türlerinin spektrumlara göre ayırt edilmesi konusunda yapılan

* Corresponding author. This is useful to know for communication with the appropriate person in cases with more than one author.

çalıřmalarda kırmızı kenar spektrumunun oldukça etkili olduđu gözlemlenmiřtir. Kırmızı kenar spektrumu bitki örtüsü yapı parametrelerine duyarlıdır, bitkilerin geniş yaprak ve Yaprak Alan Endeksi (LAI) bitkinin ayırt edilmesi için kırmızı kenar bölgesini iyi bir seçim haline getirmektedir (Jia ve ark., 2011).


Adam ve Mutanga (2009) yeřil yaprakların yakın kızılötesi ve kırmızı kenar bölgelerinde en büyük çeřitliliğe sahip olduđunu belirterek elektromanyetik spektrumun kırmızı kenar ve kızıl ötesi bölgelerinin tür tespiti ve ayırt etmedeki önemini çalıřmalarında dođrulamıřtır. Bitki örtüsü ayırt edilmesinde birçok sınıflandırma tekniđi kullanılmaktadır. Dudley ve ark. (2015) bitki örtüsü fenolojisindeki mekansal ve zamansal deđiřimlere bađlı olarak spektral yansımadaki deđiřkenlik sebebiyle dođru bitki örtüsü sınıflandırmasında oluřan sorunlara çözüm bulmak için Çoklu Son Eleman Spektral Karıřım Analizi (MESMA) yöntemini kullanmıřlardır. Tuz bataklıkları bitki toplulukları üzerinde yapılan bir çalıřmada Doğrusal Ayırıcı Analiz (LDA) ve parametrik olmayan sınıflandırma ve regresyon ađacı (CART) tekniklerinin karřılařtırması yapılmıřtır. Kahve tarlaları ve dođal bitki örtüsü arasında ayırım yapmanın zor olduđu bölgelerde yapılan bir çalıřmada kontrollü sınıflandırma tekniđi kullanılmıřtır (Martinez-Verduzco ve ark., 2012). Anchang ve ark. (2016) uydu görüntülerinden kentsel bitki örtüsü haritalama çalıřmalarında kontrolsüz sınıflandırmanın maliyetli alan çalıřmasından ziyade görüntü elde etmede kaynaklara daha fazla odaklanmasını sađladığından bir avantaj sađladığını belirtmektedir. Sınıflandırma çalıřmalarında bitki türlerine göre yukarıdakiler gibi çeřitli teknikler kullanılmaktadır.

2. MATERYAL VE YÖNTEM


2.1 Materyal

2.1.1 alıřma Alanı

alıřma alanı Mersin ili Tarsus ilçesinde bulunan Alata Bahe Kùltürleri Arařtırma Enstitüsü Müdürlüğüne ait arazide yapılmıřtır. Arazide ekili olan soya ve yonca bitkilerinin multispektral görüntüler vasıtasıyla ayırt edilmesi amaçlanmıřtır.




řekil 1. Mersin ile haritası



řekil 2: Alata Bahe Kùltürleri Arařtırma Enstitüsü Tarsus Müdürlüğü arazisi

Bitki türlerinin sınıflandırılması amacıyla bařladığımız alıřmamıza en az iki farklı bitki türünün, yonca ve soya bitkilerinin ekildiđi 4.5 hektarlık alanda alıřma yapıldı.



řekil 2. Arazideki soya (a) ve yonca (b) ekinleri

2.1.2 Donanım

Ekinlere ait görüntüler Parrot Bluegrass döner kanatlı mikro-İHA'ya entegreli Parrot Sequoia multispektral kamera ile elde edilmiřtir.



Şekil 3. Parrot Bluegrass mikro-İHA

İHA'nın teknik özellikleri:

GENEL:

- Ağırlık: 1.81 kg
- Boyut: 30.48 cm x 40.64 cm in x 14 cm
- Taşıma için çıkarılabilir pervaneler

WI-FI VE SİNYAL İLETİMİ:

- Aralık: Parrot Skycontroller 2 ile 2 km'ye kadar
- WiFi AC-type, 2 bi-band antennas (2,4 and 5GHz)

BATARYA KAPASİTESİ:

- Batarya süresi: 25 dakika
- 6700 mAh Lipo batarya

SENSÖRLER:

- Dâhili GPS + GLONASS
- Inertial Navigation System (INS)
- Altimetre
- Ultrason
- Optik akışlı dikey kamera

ÖN KAMERA:

- Fotoğraf: 14MP geniş aç kamera
- Video: 1080p Full HD
- Video yayını: 360p / 720p
- Dâhili video belleği: 32GB



Şekil 4: Araca entegre edilen kamera sistemleri

Parrot Sequoia Multispektral Kamera özellikleri:

GENEL:

- Boyut: 2.3x1.6x1.1 in
- Ağırlık: 72 gr
- Fotoğraf modu: 1 fps'ye kadar
- Dâhili hafıza: 64 GB
- Inertial measurement unit & magnetometre
- Güç: 5 W (~12 W en son)

4 KÜRESEL ÖRTÜCÜLÜ TEK-BANT KAMERA:

- Çözünürlük: 1.2 Mpx, 1280x960 piksel
- HFOV: 61.9°
- VFOV: 48.5°
- DFOV: 73.7°

4 AYRI BANT:

- Yeşil: 550nm +/- 40nm
- Kırmızı: 660nm +/- 40nm
- Kırmızı Kenar: 735nm +/- 10nm
- Yakın Kızılötesi: 790nm +/- 40nm

RGB KAMERA:

- Çözünürlük: 16 MP, 4608x3456 piksel
- HFOV: 63.9°
- VFOV: 50.1°
- DFOV: 73.5°


GÜNEŞ IŞIĞI SENSÖRÜ:

- Boyutlar: 4.57x3.81x1.78 cm
- Ağırlık: 36 gr
- 4 spektral sensör (gövde ile aynı filtreler)
- GPS
- Inertial measurement unit & magnetometre
- SD Kart girişi
- Güç: 1 W

Parrot Sequoia multispektral kamera sistemi iki parçadan oluşmaktadır. İlki dört farklı spektral bant ile RGB sensöre sahip olup eşzamanlı küresel deklanşör sistemiyle görüntüleri elde eden kamera, ikincisi ise kamerayla tamamen entegreli güneş ışığı sensörüdür. Bu sensör mevcut aydınlatma koşullarını yakalayıp kaydını tutarak mutlak bir ölçüm için kamera çıktılarını otomatik olarak kalibre eder.

2.2 Yöntem

Ekinlere ait görüntüler fotogrametri yöntemiyle elde edilip işlendi. Bu çalışmada uygulanan yöntemde İHA için gereken uçuş planı, Pix4D firması tarafından sağlanan uçuş planlayıcı mobil uygulaması ile oluşturuldu. Uçuş, belirlenen çalışma alanı içinde %80 boyuna ve enine bindirme oranında, yer örnekleme aralığı (YÖA/GSD) yaklaşık 7 cm olacak şekilde gerçekleştirildi. Bunun yanında uçuşun güneş ışınlarının en yüksek yansımaya seviyesine sahip olduğu öğle saatinde yapılmasına dikkat edildi. Uçuşa başlamadan önce ortamın güneş ışığı yansımaya değerlerinin belirlenip görüntülerin kalibre edilmesi için spektral kalibrasyon kağıdının görüntüleri multispektral kamera ile edinildi (Şekil 5).




Şekil 5. Spektral kalibrasyon kağıdının görüntüsünün İHA'ya monteli multispektral kamera ile alınması. a) yeşil b) yakın kızıl ötesi c) kırmızı d) kırmızı-kenar görüntüler

Saat 11.30'da uçuşa başlayan İHA seyrini yaklaşık 10 dk sürdürmüş olup multispektral görüntüleri başarılı bir şekilde edindi. Bu uçuş sonucunda toplamda 1665 adet görüntü elde edilmiştir. Yeşil, kırmızı, kırmızı-kenar, yakın kızıl ötesi ve RGB bantlarının her birinden 333 tane görüntü toplanmıştır. Bu görüntülerden RGB hariç diğer banttaki görüntüler (yeşil, kırmızı, kırmızı-kenar, yakın kızıl ötesi) işlenmek üzere Pix4D yazılımına aktarıldı. Pix4D yazılımı, Structure from Motion (SfM) algoritması ile çalışmakta ve görüntüleri ışın demetleriyle blok dengeleme yaparak işlemektedir. Bu çalışmada yazılımın multispektral görüntüleri işlemesi için tarım uygulamalarına yönelik modülü kullanıldı. Kalibrasyon kağıtlarının görüntüleri yazılıma tanıtılarak spektral kalibrasyon yapıldıktan sonra görüntüler yöneltme işlemine tabi tutulup arazi yüzeyinin 3B modelinin tahmini şekli seyrek nokta bulutu ile oluşturuldu. Akabinde yoğun nokta bulutu oluşturulup üzerinden yüzey geçirilmiştir. Sonrasında ise her bir bant için ayrı ayrı 7.81 cm yer örnekleme aralığına sahip ortofoto üretildi. Ortofotolar ESRI ArcGIS yazılımında işlenmek üzere .tif biçiminde dışarı çıkarıldı.



Şekil 6. Ekin arazisine ait kızıl ötesi bandındaki ortofoto

Her bir bant ArcGIS yazılımının içine aktarıldı ve sınıflandırma çalışmalarına altlık olmak üzere birleştirilerek kompozit görüntü elde edildi. Yeşil, kırmızı, kırmızı-kenar ve yakın kızıl ötesi bantları ihtiva eden kompozit görüntü ArcToolbox modülü ile üretildi (Şekil 7).



Şekil 7. 4 bantın birleştirilmesiyle oluşan kompozit false color görüntü

Çalışmamızda 1 adet kontrolsüz ve 2 adet kontrollü sınıflandırma yapılarak doğruluk analizi yapıldı. Sınıflandırma çalışmaları aşağıdaki başlıklar altında anlatılmaktadır.

- a) Kontrolsüz Sınıflandırma
 - i) ISO data cluster
- b) Kontrollü Sınıflandırma
 - i) Maximum Likelihood
 - ii) Support Vector Machine


2.2.1 Kontrolsüz sınıflandırma

Kontrolsüz sınıflandırma; piksellerin, kullanıcı müdahalesi olmadan otomatik olarak kümelenirilmesi temeline dayanmaktadır. Bu çalışmada kontrolsüz sınıflandırma yöntemlerinden ISO data cluster kullanılmıştır.

2.2.1.1 ISO Data Cluster

ISO cluster algoritması, her aday hücreyi bir kümeye atarken minimum Öklid mesafesini hesaplamak için kullanılan iteratif bir işlemdir. Süreç, her küme için bir tane olmak üzere, yazılım tarafından atanan keyfi değerlerle başlar (tarafımızdan girilen küme sayısı ile). Her hücre, bu değerlerin en yakınına atanır. İlk iterasyondan sonra kümeye ait olan hücrelerin öznitelik mesafelerine bağlı olarak her küme için yeni değerler yeniden hesaplanır.

Çalışma alanında 4 adet sınıf belirlenmiş olup bunlar soya, yonca, toprak ve yabani ot olarak ayrılmıştır. Ancak kontrolsüz sınıflandırmada eğitim bölgeleri işaretlenmediğinden programa 5 tane sınıflandırma yapması komut verilmiştir. İşlem sonucu oluşan sınıflandırma haritası aşağıdadır (Şekil 8).




Şekil 8. ISO cluster sınıflandırma

2.2.2 Kontrollü Sınıflandırma

Kontrollü sınıflandırmada görüntünün hangi sınıflara ayrılacağı, ya da görüntüden hangi sınıfların elde edilmek istenildiği önceden bilinir. Bunun için görüntüden belirlenen sınıflara ait denetim alanlarının seçilmesi gerekmektedir. Bu seçim için gerektiğinde arazide yer gerçekliği yapılması zorunludur. Kontrol alanlarının seçimi sınıflandırmanın doğruluğunu etkileyen bir aşamadır.


2.2.2.1 Maximum Likelihood

Bu sınıflandırma algoritması her banttaki her bir sınıf için istatistiklerinin normal olarak dağıtıldığını ve belirlenmiş bir pikselin belli bir sınıfa ait olma olasılığını hesaplar. Kompozit görüntü üzerinde niteliği bilinen alanlar algoritmaya tanıtılarak eğitildi (Şekil 9).



Şekil 9. Eğitim alanları

Bu eğitilmiş alanlara ait pikseller sayesinde diğer tüm piksellerin sınıfı tahmin edildi. Belirlenen 4 adet sınıf için eğitilen alanlar baz alınarak sınıflandırma haritası oluşturuldu. ArcGIS yazılımında Arctoolbox modülü ile oluşturulan sınıflandırma haritası şekil 10'daki gibidir.



Şekil 10. Maximum Likelihood sınıflandırma

2.2.2.2 Support Vector Machine

Support Vector Machine (SVM), genellikle karmaşık ve gürültülü verilerden iyi bir sınıflandırma sonucu veren istatistiksel öğrenme teorisinden türetilmiş bir denetimli sınıflandırma yöntemidir. Bu yöntemde de maximum likelihood yönteminde kullanılan eğitim alanları kullanıldı (Şekil ixxx). Söz konusu eğitim alanları arazi gerçeğinde niteliği bilinen ve görüntüde açıkça belirli olan kısımlardan çizildi.

2.3 Doğruluk Değerlendirmesi

Doğruluk değerlendirmesi, uzaktan algılamada görüntü sınıflandırmasında bir piksele atanan sınıf etiketi ile gerçek değer arasındaki uygunluğun ortaya konmasıdır. Gerçek sınıf, arazide bulunan nesnelerin hava fotoğraflarından ya da mevcut harita ve planlardan doğrudan veya dolaylı olarak gözlemlenir. Gerçek sınıf arazi çalışması esnasında yapılan gözlemler yardımıyla doğrudan görüntü üzerinden belirlenmiştir.

Doğruluk değerlendirmesinde kullanılmak üzere sınıflandırılmış görüntü üzerine örneklem noktaları atılması gerekmektedir. Örneklem noktalarının adedi görüntünün toplam piksel sayısına göre hesaplandı ve en az 289 adet nokta gerektiği tespit edildi. Bu hesaplama toplamda 300 adet nokta görüntü üzerine otomatik olarak rastgele atıldı. Bu işlem ArcGIS yazılımının ArcToolbox modülü ile gerçekleştirildi. Bu modül sayesinde noktaların altlık olarak kullanılan sınıflandırma haritalarında denk geldiği piksel değeri otomatik olarak öznitelik tablosuna aktarılmıştır. Yer gerçekliği ise kompozit görüntü üzerinden öznitelik tablosuna el ile girildi. Her bir sınıf numaralandırılmış olup sırasıyla 1=soya, 2=yonca, 3=toprak ve 4=yabani ot olarak kodlandı. Örneklem noktalarının konumu aynı kalacak şekilde her bir sınıf için farklı öznitelik tablosu oluşturuldu. Öznitelik tabloları ile hata matrisleri oluşturuldu.

Maximum Likelihood sınıflandırma için oluşturulan hata matrisi Tablo 1'de olduğu gibidir.

Sınıf	Soya	Yonca	Toprak	Yabani Ot	Toplam	Kullanıcı Doğruluğu	Kappa
Soya	84	2	0	11	97	0.87	
Yonca	0	14	0	0	14	1.00	
Toprak	1	0	121	4	126	0.96	
Yabani Ot	18	0	3	42	63	0.67	
Toplam	103	16	124	57	300	0.00	
Üretici Doğruluğu	0.82	0.88	0.98	0.74	0	0.87	
Kappa							0.81

Tablo 1. Test alanına ilişkin Maximum Likelihood sınıflandırma performansı; Hata Matrisi

Soya, yonca, toprak ve yabani ot sınıflarının üretici doğruluğu ve kullanıcı doğruluğunun karşılaştırması Tablo 1’de verilmiş olup ortalama doğruluk %87 olarak hesaplanmıştır. Kappa değeri ise %81 olarak hesaplanmış olup;

- 1.00 tam uyum olduğunu,
- 0.75 ve fazlası sınıflandırma performansının çok iyi olduğunu,
- 0.40’ ın aşağısı ise performansın yetersiz olduğunu,

- 0.00 ise sınıflandırılmış ve referans verileri arasında uyumun olmadığını gösterir.

Bu durumda Maximum Likelihood sınıflandırma işleminin performansının çok iyi olduğu söylenebilir.

Support Vector Machine sınıflandırma işlemi için oluşturulan hata matrisi Tablo 2’de olduğu gibidir.

Sınıf	Soya	Yonca	Toprak	Yabani Ot	Toplam	Kullanıcı Doğruluğu	Kappa
Soya	77	0	0	8	85	0.91	0
Yonca	1	12	0	0	13	0.92	0
Toprak	2	0	123	18	143	0.86	0
Yabani Ot	23	4	1	31	59	0.53	0
Toplam	103	16	124	57	300	0	0
Üretici Doğruluğu	0.75	0.75	0.99	0.54	0	0.81	0
Kappa	0	0	0	0	0	0	0.71

Tablo 2. Test alanına ilişkin Support Vector Machine sınıflandırma performansı; Hata Matrisi

Support Vector Machine sınıflandırma performansına ilişkin hata matrisindeki toplam doğruluk %81 olup kappa değeri %71 olarak hesaplanmıştır. Buna göre sınıflandırmanın iyi bir performans sergilediği söylenebilir.

3. SONUÇ

Bu çalışmada yonca ve soya bitkilerinin ekildiği araziden multispektral görüntüler elde edildi. Görüntüler çeşitli yazılımlarda işlenerek üç farklı algoritma ile sınıflandırıldı. Bu sınıflandırma çalışmalarının doğruluğu incelendi. Yapılan sınıflandırmalarda aynı eğitim bölgeleri ve örneklem noktaları kullanıldı. Sınıflandırmalar sonucu Maximum Likelihood için doğruluk %87, Support Vector Machine için ise %81 olarak hesaplandı. Bu istatistiki bilgilere göre çalışmamız için en iyi sonucu veren sınıflandırma algoritmasının Maximum Likelihood olduğu ortaya çıkmıştır.

TEŞEKKÜR

Bu çalışmanın tamamlanması için yardımlarından dolayı Paksoy Teknik A.Ş.’ye ve Alata Bahçe Kültürleri Araştırma Enstitüsüne teşekkür ederiz.

KAYNAKLAR

Adam, E. ve Mutanga, O., 2009, Spectral discrimination of papyrus vegetation (*Cyperus papyrus* L.) in swamp wetlands using field spectrometry, *ISPRS Journal of Photogrammetry and Remote Sensing*, 64 (6), 612-620.

Ahmad, A., Tahar, K. N., Udin, W. S., Hashim, K. A., Darwin, N., Hafis, M., Room, M., Hamid, N. F. A., Azhar, N. A. M. ve Azmi, S. M., 2013, Digital aerial imagery of unmanned aerial vehicle for various applications, *Control System, Computing and Engineering (ICCSCE)*, 2013 IEEE International Conference on, 535-540.

Anchang, J. Y., Ananga, E. O. ve Pu, R., 2016, An efficient unsupervised index based approach for mapping urban vegetation from IKONOS imagery, *International Journal of Applied Earth Observation and Geoinformation*, 50, 211-220.

Dudley, K. L., Dennison, P. E., Roth, K. L., Roberts, D. A. ve Coates, A. R., 2015, A multi-temporal spectral library approach for mapping vegetation species across spatial and temporal phenological gradients, *Remote Sensing of Environment*, 167, 121-134.

Fassnacht, F. E., Latifi, H., Stereńczak, K., Modzelewska, A., Lefsky, M., Waser, L. T., Straub, C. ve Ghosh, A., 2016, Review of studies on tree species classification from remotely sensed data, *Remote Sensing of Environment*, 186, 64-87.

Ishida, T., Kurihara, J., Viray, F. A., Namuco, S. B., Paringit, E. C., Perez, G. J., Takahashi, Y. ve Marciano, J. J., 2018, A novel approach for vegetation classification using UAV-based hyperspectral imaging, *Computers and Electronics in Agriculture*, 144, 80-85.

Jia, K., Wu, B., Tian, Y., Li, Q. ve Du, X., 2011, Spectral discrimination of opium poppy using field spectrometry, *IEEE*

Transactions on Geoscience and Remote Sensing, 49 (9), 3414-3422.

Martínez-Verduzco, G. C., Galeana-Pizaña, J. M. ve Cruz-Bello, G. M., 2012, Coupling Community Mapping and supervised classification to discriminate Shade coffee from Natural vegetation, Applied Geography, 34, 1-9.

Peña, J., Torres-Sánchez, J., Serrano-Pérez, A., de Castro, A. ve López-Granados, F., 2015, Quantifying Efficacy and Limits of Unmanned Aerial Vehicle (UAV) Technology for Weed Seedling Detection as Affected by Sensor Resolution, Sensors, 15 (3), 5609.

Salamí, E., Barrado, C. ve Pastor, E., 2014, UAV Flight Experiments Applied to the Remote Sensing of Vegetated Areas, Remote Sensing, 6 (11), 11051.

Somers, B. ve Asner, G. P., 2014, Tree species mapping in tropical forests using multi-temporal imaging spectroscopy: Wavelength adaptive spectral mixture analysis, International Journal of Applied Earth Observation and Geoinformation, 31, 57-66.